

時系列解析および異常検知に関する技術動向

Technology Trends in Time Series Analysis and Anomaly Detection

小縣信也*

1. はじめに

時系列解析とは、ある現象の時間的な変動を捉えるための解析の総称である。本分野に関する研究の歴史は古く、自己回帰モデルや状態空間モデルなど、様々な伝統的なモデリング手法が存在する。一方、近年の深層学習の飛躍的な発展に伴い、昨今では時系列解析においても畳み込みニューラルネットワークや Transformer をはじめとする深層学習によるモデリングが盛んに研究されている。本稿では、時系列解析における近年の技術動向について俯瞰する。また、時系列解析を応用した時系列データにおける異常検知についても取り扱う。

2. 時系列解析

時系列解析におけるモデリング手法は、伝統的な自己回帰モデルや、ベイズ統計学の考え方を取り入れた状態空間モデル、機械学習を用いた手法など

様々である。また、時系列解析ではモデリングだけでなく、データの性質にも着目する必要がある。これらに応じた適切な前処理を行うことが重要となる。

2.1 時系列データ

時系列データとは、時間的順序を伴って観察されるデータである。時系列データの例として、発電量などのセンサーデータ、気象データ、販売数データなどが挙げられる。時系列データには以下に示す3つの重要な特徴がある。

1つ目は、データが時間に依存しないノイズを含むことである。ノイズとは分析に必要とされない情報であり、主に高周波数成分として観測される。

2つ目は、データが周期性を持つことである。データから一定期間ごとに繰り返される傾向が観測されるとき、データは周期性を持つという。例えば気温データの場合、1日ごとの周期や1年ごとの周期が観測される。

表1 時系列解析モデルの比較

	解釈性	計算負荷	モデリングの難易度	モデルの表現力
機械学習 (深層学習以外)	低い (ただし、線形回帰や決定木などは結果を解釈しやすい)	低い	易しい	低い
機械学習 (深層学習)	低い	高い	難しい	高い
自己回帰系モデル	高い	低い	易しい	低い
状態空間モデル	高い	高い	難しい	高い

* スキルアップ AI 株式会社 取締役 CTO
(〒101-0061 東京都千代田区神田三崎町三丁目3-20)
e-mail : s_ogata@skillupai.com

3つ目は、トレンドと呼ばれる長期的な変動傾向が観測されることである。例えば図1のデータでは、長期的に値が上昇している傾向がみられ、上昇トレンドが観測される。トレンドの発生は、観測時間ごとにデータを生成する確率分布が異なり得ることを示し（これを分布が非定常であるという）、特に注意が必要である。

2.2 時系列データの前処理・分析

時系列解析では、通常のデータ分析における前処理に加え、前述のようなデータ特性を考慮した事前分析が重要となる。まず、データのトレンドの有無を判断する必要がある。トレンドの分析は移動平均などを用いて行う。トレンドが認められた場合、時系列の変換を行うことでトレンド成分をある程度取り除くことができる場合がある。隣り合う各時刻の差を取った差分系列はその代表的な例である。

次に、高速フーリエ変換や自己相関係数などを利用して、データの周期性を明らかにする。得られた周期性の特徴は、後述の時系列解析モデルのパラメータ設定などに役立てることができる。

2.3 時系列解析におけるタスク

時系列解析のタスクは、主に教師あり学習（回帰および分類）と教師なし学習に分けられる。例えば、発電量の予測や気温の予測等は回帰タスクであり、環境音の分類や話者の分類等は分類タスクである。センサーデータを用いた異常検知やシステムログを用いた不正検知等のタスクには、教師なし学習を適用できる。

2.4 時系列モデリングの3つのアプローチ

時系列解析のモデリングには、自己回帰系モデル、状態空間モデル、機械学習手法の3種類のアプローチが存在する（表1）。自己回帰系モデルは比較的古典的な方法で、これにはARMAモデルやARIMAモデルなどが含まれる。状態空間モデルには、カルマンフィルタ、粒子フィルタ、MCMCなどの手法がある。機械学習手法によるアプローチとは、一般の機械学習のモデルを時系列データに適用

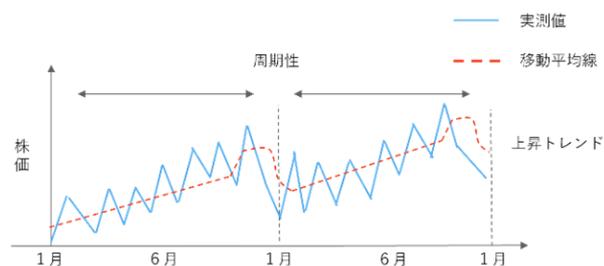


図1 株価の周期性とトレンド

するものであり、深層学習をはじめとする様々なモデルがこれの対象となる。表1に各アプローチの解釈性、計算負荷、モデリングの難易度、モデルの表現力を示す。一般に機械学習手法は、解釈性が低いが、モデル次第で大きな表現力を獲得でき、精度を求める場合に有用である。一方で自己回帰系モデルや状態空間モデルは解釈性が高く、説明可能なモデルを構築する必要がある場合に適している。

3. 時系列解析に用いられる機械学習手法

時系列解析には、様々な機械学習手法を用いることができる。もとの時系列データから、直近 n 時刻分のデータを取り出し、それを特徴量として用いる。このようにして取り出されたデータを部分時系列と呼ぶ。部分時系列に変換することによって、線形回帰、 k -近傍法、決定木など、基本的な機械学習手法の全てを利用することが可能である。本稿では特に畳み込みニューラルネットワーク（Convolutional Neural Network, CNN）や再帰型ニューラルネットワーク（Recurrent Neural Network, RNN）、Transformer といった深層学習モデルについて紹介する。

3.1 部分時系列への変換

自己回帰系モデルなど、従来の時系列解析モデルでは時系列のすべてを一度にモデルへ入力するが、一般の機械学習のモデルでは、長い系列を入力とするのは難しい。そこで、時系列を部分時系列に変換し、変換後の各部分時系列をモデルの入力とする（図2）。まず、各時刻 t において、 t を起点とした長さ n （図2では $n = 3$ ）のデータを取り出し、部分時系列群を作成する。各部分時系列の系列長は互いに等しいため、これを次元 n の説明変数として扱うことができる。時刻 $t + 1$ のデータを目的変数とし、上記の部分時系列と紐づけることで、一般の機械学習手法に入力可能なデータセットを作成できる。

3.2 時系列解析における深層学習モデル

近年様々な分野で躍進を続けている深層学習は、時系列解析でも盛んに研究されており、さまざまなモデルが提案されている。

3.2.1 畳み込みニューラルネットワーク（CNN）

CNNは深層学習モデルの一種で、畳み込みやプーリングによる特徴抽出機構を有するニューラルネットワークである。このCNNは、近年画像データへの応用で多くの成功を収めているが、時系列データにも適用可能である。時系列データでは通常1次元畳み込みが用いられる（図3）。図3では簡単なた

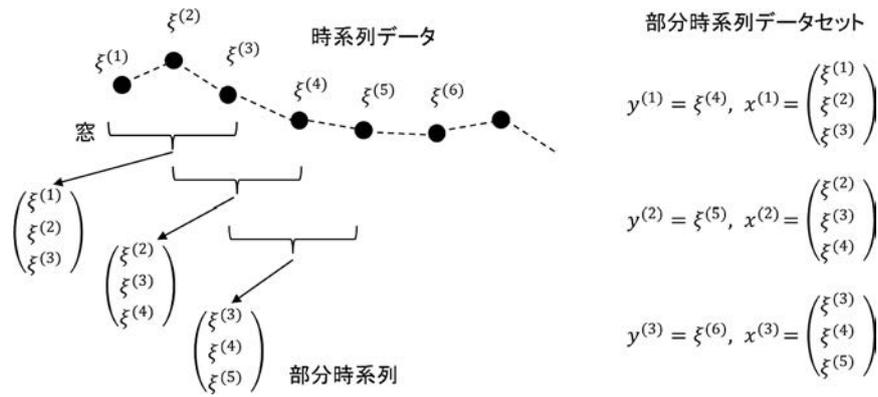


図2 部分時系列データセットの作成

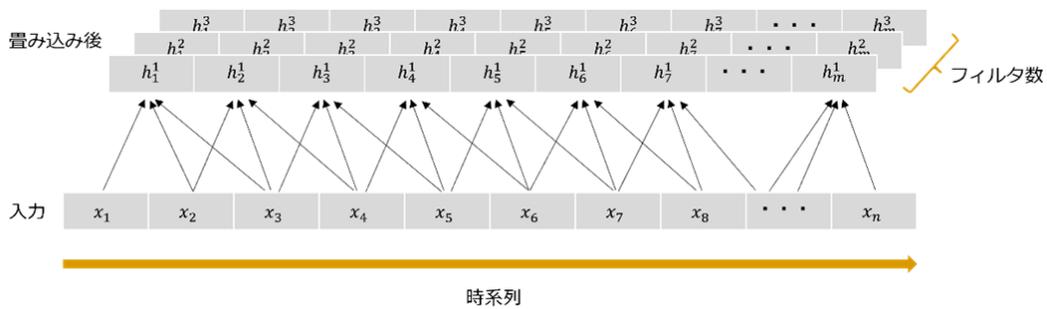


図3 1次元畳み込みの概念図

め入力時系列が単変数の場合を示しているが、多変数でも入力可能である。その場合は各変数を画像におけるチャンネルと同じように考え、1次元畳み込みを適用する。また、深層学習モデルの特筆すべき点として、モデル構造における柔軟性が非常に高く、様々な入力データを扱えることが挙げられる。例えば同じ性質の観測データが異なる地点で得られる場合、各時系列データは座標によりマッピングされた3次元データとして表現できる。従来の時系列解析モデルではこのようなデータを情報の損失なく入力することは困難であったが、CNNであればこれらをそのまま入力可能である。このようなデータへのCNNの適用例として、鈴木らによる集中豪雨の発生予測研究が挙げられる¹⁾。この研究では、各観測地点での多変数気象変数の時系列を入力とし、2次元畳み込みによって集中豪雨の予測を行った。CNNのアーキテクチャを活用することで、多次元の時系列データを効果的にモデリングした事例である。

3.2.2 再帰型ニューラルネットワーク (RNN)

RNNとは時間方向に状態を引き継ぐことができるニューラルネットワークである。各時刻の出力を次の時刻の入力に追加する再帰的な構造が特徴である。代表的なモデルとしてLSTMやGRUなどが挙

げられる。テキストデータへの応用例が多いが、時系列データにも適応可能である。

通常のRNNは、その再帰的な構造から計算の並列化が難しく、計算コストが高い。そこでShallow RNN²⁾のように構造を工夫し、推論時間を削減できるモデルが提案されている。この手法では、1層目でいくつかの独立したRNNブロックによって並列に部分時系列を処理し、続く2層目で1層目の出力を利用して長期的な依存関係を捉える。1層目の計算において並列計算が可能であり、標準的なRNNに比べて推論時間を短く抑えることができる。

3.2.3 Transformer

RNNには、上述の通り計算効率が悪いという欠点があった。そこで、RNNを用いずに機械翻訳問題を解くため、Transformer³⁾と呼ばれるモデルが提案された(図4)。TransformerはAttention機構によって、各時刻の変数の相互作用を効率的に抽出する。

AttentionはRNNのような再帰構造を持たないため、RNNと比較して学習効率が非常に高い。また多くのタスクで精度が良いことから、昨今の自然言語処理モデルで主流となっている。一方で、時系列データに対してもTabBERTおよびTabGPT⁴⁾といったTransformerの構造を元にしたモデルが

数多く提案されている。TabBERTでは、その元となったBERT同様時系列の埋め込み表現を得ることができる。TabGPTはデータの生成過程を表現する生成モデルのひとつであり、データ拡張などを目的とした時系列データの生成に用いることができる。

4. 異常検知

異常検知は、与えられたデータが正常か異常かを判別するタスクである。外れ値の検出や、周期性から逸脱する異常部位の検出などに用いられる。時系列データについては、ここまで述べた時系列モデルに回帰タスクを解かせ、その予測値を元に異常検知を行うことができる。異常検知においても、深層学習を用いたモデルが盛んに研究されている。

4.1 異常検知タスクの基本的な考え方

異常検知は上述の通り正常か異常かを判別するタスクであり、教師あり分類タスクとして定式化できる。しかし、異常検知ではタスクの性質上、異常データがほとんど、あるいは全く手に入らないことが多く、一般に非常に不均衡なラベル分布を持つ分類タスクになる。そのため、通常の機械学習手法ではうまく学習できないことが多い。そこで、正常データのパターンを定義し、そこから大きく外れたものを異常として判定することを考える。正常データからの逸脱の度合いを測る方法としては、距離や尤度などが挙げられる。これらを異常度として定義し、その数値の大小によって異常かどうかを判別する。なお、各データに対する正常、異常のラベル付けは手動で行う必要がある。

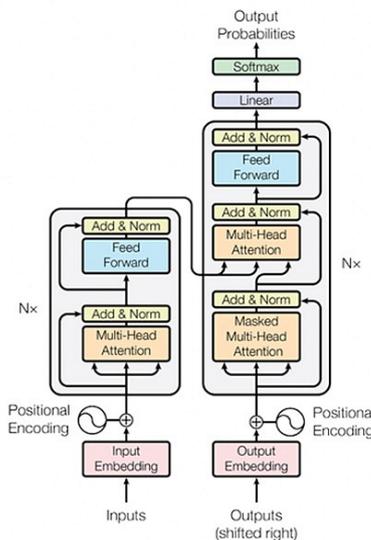


図4 Transformerの構造(文献3)より引用

図5は、ある体重データ⁵⁾に対する分布推定による異常検知の例である。この例では、観測データにおける尤もらしい正規分布を推定し、各データ点の推定確率密度を異常度として定義している。例えば図5では110 kg以上の確率密度は十分小さく、120 kgや160 kg付近の値は異常値と判定できる。

4.2 時系列データに対する異常検知の適用

時系列データにおいて異常検知を行う場合、異常度の算出に学習済み時系列解析モデルの予測値を用いる。すなわち、任意の学習済みモデルの時刻 t での出力を、時刻 t における正常値の期待値とみなし、観測値との差から異常度を計算する(図6)。この定義では、観測値は期待値の周辺で正規分布に従って観測されると仮定している。観測値と期待値の差が大きいことは、観測値が観測される尤度が低いことを意味する。

4.3 深層学習による異常検知

異常検知タスクではGMMやSVDDといった機械学習手法が存在しているが、本分野においても深層学習モデルによる応用が盛んに研究されている。

4.3.1 自己符号化器(Auto Encoder)

自己符号化器は、入力データを復元できるように

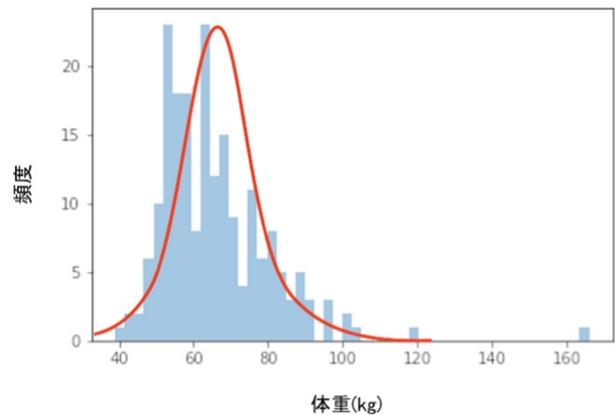


図5 分布推定による異常検知例

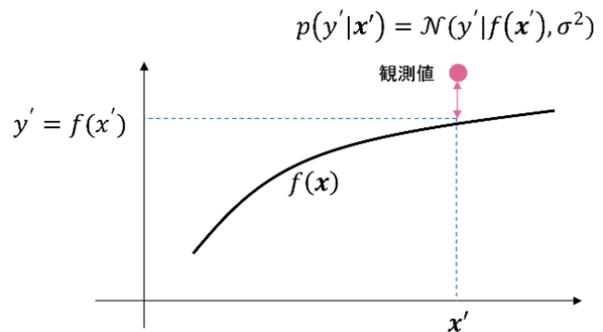


図6 時系列データにおける異常検知

学習を行うニューラルネットワークである(図7)。恒等変換を学習してしまうことを防ぐため、通常は中間層のノード数は入力次元よりも小さくする。次元圧縮などに適用される手法であるが、異常検知に応用できることが知られている⁶⁾。異常検知に自己符号化器を用いる場合、正常データのみを用いて学習を行う。このようにすることで、学習データと分布の異なる異常データを上手く復元できず、正常データのみ復元可能なモデルを得ることができる。そこで、異常度を入力と出力の差である再構成誤差で定義することで、異常検知が可能となる。

4.3.2 GAN (Generative Adversarial Networks)

GANは、画像生成モデルとして提案された深層学習モデルであり、生成器Gと識別器Dの二つのモデルで構成される。Dは、Gが生成したデータまたは本物のデータを入力とし、入力されたデータが生成物か本物かを判別できるように学習を行う。一方Gは、潜在変数(ノイズ)を入力とし、Dの識別精度が下がるようなデータを生成できるように学習を行う。両者を同時に学習することで、本物のデータと類似したデータを生成できるGを構築できる。GANには様々な派生形が提案されており、その中にBiGAN⁷⁾と呼ばれるモデルがある。このBiGAN

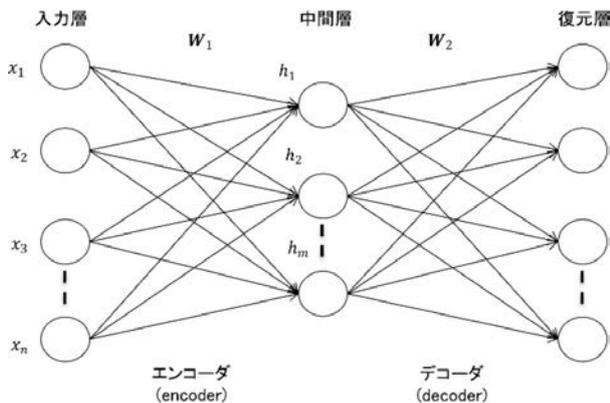


図7 自己符号化器

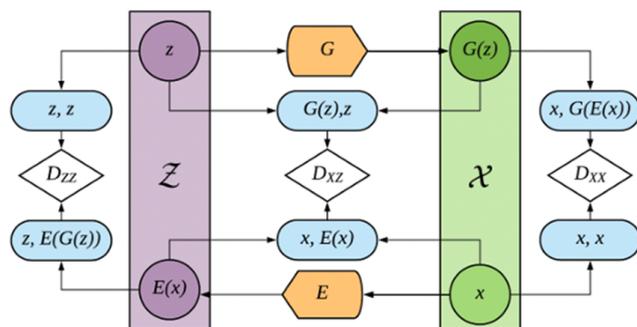


図8 BiGANによる異常検知(文献8より引用)

を用いて異常検知を行う手法が提案されている⁸⁾。BiGANの特徴は、エンコーダEを導入し、生成器Gに入力する潜在変数を入力データから予測している点である。学習済みのEの出力は、入力データの分布を反映した分布を持つと考えられる。そこで、BiGANでは、あらかじめ正常データのみで学習しておき、その後、テストデータをE、Gの順に渡すことによって新しいデータを生成し、その生成されたデータと元のテストデータを比べることによって異常を判定する(図8)。このとき、異常データでは入力の分布が正常データと異なるはずであるから、Eの出力も学習時の分布と異なるはずであり、このことからGは入力をうまく復元できないと考えられる。この原理を利用して異常検知を行う。

4.3.3 ハイブリッドモデル

ハイブリッドモデルとは、オートエンコーダーなどの教師無し学習によって学習されたニューラルネットワークにより抽出した潜在特徴量を用いて、従来の手法による異常検知を行う手法である。例えば、オートエンコーダーを用いて中間層の特徴量を取り出し、取り出した特徴量をGMMやSVDDといった従来のモデルで利用する方法がある。

5. 結び

本稿では、時系列解析における近年の技術動向について俯瞰した。近年の深層学習の飛躍的な発展に伴い、時系列解析においてもCNNやTransformerをはじめとする深層学習によるモデリングが盛んに研究されていることを紹介した。

参考文献

- 1) 鈴木 紹晟, キム スンミン, 立川 康人, 市川 温, 萬 和明, 豪雨の発生予測に対する畳み込みニューラルネットワークの応用, 土木学会論文集B1(水工学), 74(5), I_295-300(2018)
- 2) D. Dennis, et al., Shallow RNN: Accurate Time-series Classification on Resource Constrained Devices, Advances in Neural Information Processing Systems, 32, 1-11(2019)
- 3) A. Vaswani, et al., Attention Is All You Need, Proceedings of the 31st International Conference on Neural Information Processing Systems, 31(Dec. 2017), 6000-6010, Long Beach California, USA.
- 4) I Padhi et al., Tabular Transformers for

- Modeling Multivariate Time Series, ICASSP 2021 (Jun, 2021), 21144182, Toronto, ON, Canada.
- 5) Vincent Arel-Bundock's Github projects, R datasets, Davis データ (accessed May. 29 2023), URL : <https://vincentarelbundock.github.io/Rdatasets/doc/carData/Davis.html>
- 6) M. Sakurada, T. Yairi, Anomaly Detection Using Autoencoders with Nonlinear Dimensionality Reduction, Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis (Dec, 2014), 4-11, Gold Coast Australia QLD Australia.
- 7) J. Donahue, P. Krähenbühl, T. Darrell, ADVERSARIAL FEATURE LEARNING, 5th International Conference on Learning Representations (Apr, 2017), Toulon, France.
- 8) H. Zenati, M. Romain, C. Foo, B. Lecouat, and V. Chandrasekhar, Adversarially Learned Anomaly Detection, 2018 IEEE International Conference on Data Mining (Nov, 2018), 727-736, Singapore.

著者略歴



小縣信也 (オガタ シンヤ)

大阪市立大学工学部卒業後、建材メーカー、設備設計事務所に勤務。2010年にOpenFOAM勉強会 for beginner (現オープンCAE勉強会@関東) を立ち上げ3年間幹事を務める。1級建築士、エネルギー管理士。2013年に国土交通省国土技術政策総合研究所 優秀技術者賞受賞。日本ディープラーニング協会主催 2018E 資格試験 優秀賞受賞、2019#1E 資格試験優秀賞受賞。